

# RELCASI

---

Volume 11 | Issue 2

Article 3

---

7-1-2019

## The use of prediction models for foresight intelligence: a case study in subscribers' acquisition for the news portal GaúchaZH

Luccas Martins da Rosa  
*UFRGS*, [martins.luccas@hotmail.com](mailto:martins.luccas@hotmail.com)

Raquel Janissek-Muniz  
*PPGA/EA/UFRGS*, [rjmuniz@ufrgs.br](mailto:rjmuniz@ufrgs.br)

Follow this and additional works at: <https://aisel.aisnet.org/relcasi>

---

### Recommended Citation

Rosa, Luccas Martins da and Janissek-Muniz, Raquel (2019) "The use of prediction models for foresight intelligence: a case study in subscribers' acquisition for the news portal GaúchaZH," *RELCASI*: Vol. 11 : Iss. 2 , Article 3.

DOI: 10.17705/1relc.00068

Available at: <https://aisel.aisnet.org/relcasi/vol11/iss2/3>

This material is brought to you by the AIS Journals at AIS Electronic Library (AISeL). It has been accepted for inclusion in RELCASI by an authorized administrator of AIS Electronic Library (AISeL). For more information, please contact [elibrary@aisnet.org](mailto:elibrary@aisnet.org).



Latin American and Caribbean Journal of the Association for  
Information Systems

Revista Latinoamericana Y Del Caribe De La Asociación De  
Sistemas De Información

Revista Latino-americana e Caribenha da Associação de Sistemas  
de Informação

Research Paper

DOI: 10.17705/3relc.00068

ISSN: 1937-8831

## **The use of prediction models for foresight intelligence: a case study in subscribers' acquisition for the news portal GaúchaZH**

## **El uso de modelos de predicción para generación de inteligencia: un caso de la adquisición de suscriptores al portal GaúchaZH**

## **Uso de modelos de predição para geração de inteligência: um estudo de caso em aquisição de assinantes do portal GaúchaZH**

**Luccas Martins da Rosa**

UFRGS

Porto Alegre - RS, Brasil

*martins.luccas@hotmail.com*

**Raquel Janissek-Muniz**

PPGA/EA/UFRGS

Porto Alegre - RS, Brasil

*rjmuniz@ufrgs.br*

### **Abstract**

With the increase in capacity for generating, capturing and processing data, especially at digital product and services market, the utilization of these methods by organizations is also expanding. Data-driven companies, as those in which strategic decision processes are totally anchored in real data are called, increase in number and encourage several organizations from different segments start extracting value from it's data. This article was made based in a case study in which data processing methods were applied in order to extract foresight intelligence to optimize ROI of marketing efforts in acquiring digital services subscribers. The case belongs to Grupo RBS, specifically GaúchaZH's digital signatures team, a local publisher news that has fifteen million unique users monthly as average. This research's goal is to analyze the utilization of predictive analysis to extract intelligence for marketing tactics. Therefore, the research presents itself as a source of references for developments in the use of predictive methodologies to increase ROI in marketing and its effectiveness as well.

**Keywords:** Foresight Intelligence; Predictive models; Marketing.

### **Resumen**

Con el aumento de la capacidad para generación, captura y procesamiento de datos, especialmente en el mercado de productos y servicios digitales, los usos de estos métodos por parte de las organizaciones también se están expandiendo. Las empresas impulsadas por datos, cómo denominanse las empresas con procesos de decisión estratégica totalmente anclados en datos reales, aumentan en número y alentan a varias organizaciones de diferentes segmentos a empezar extraer valor de los datos que tienen. Este artículo se elaboró a partir de un caso de estudio en que se aplicaron metodologías de procesamiento de datos al fin de extraer inteligencia anticipada para optimizar el ROI de los esfuerzos de marketing para la adquisición de suscriptores en un servicio digital. El caso utilizado pertenece al Grupo RBS, específicamente al equipo de suscripción digital de GaúchaZH, un portal noticioso local con media de quince millones de usuarios únicos mensuales. El objetivo de esta investigación es analizar el uso del análisis predictivo para extraer inteligencia en tácticas de marketing. Se concluye que la aplicación consciente de datos en las organizaciones representa un importante diferencial estratégico, especialmente en un escenario en el que muchos actores aún se encuentran en etapas incipientes de procesamiento de

sus informaciones. Por tanto, la investigación presentase como fuente de referencias para evoluciones en el uso de metodologías predictivas para incrementar la efectividad del marketing y su ROI.

**Palabras clave:** Inteligencia Anticipativa; Modelos predictivos; Marketing.

---

## Resumo

---

Com o aumento da capacidade de geração, captação e tratamento de dados, sobretudo no mercado de serviços e produtos digitais, ampliam-se também os usos desses métodos pelas organizações. As *data-driven companies*, como são chamadas as empresas com processos de decisão estratégica totalmente ancoradas em dados reais, aumentam em número e incentivam que diversas organizações, de variados segmentos, também comecem a extrair valor dos dados que possuem. O presente artigo foi elaborado a partir de um estudo de caso no qual foram aplicados processos de tratamento de dados com o objetivo de extrair inteligência antecipativa para otimizar o ROI dos esforços de *marketing* para aquisição de assinantes em um serviço digital. O caso utilizado pertence ao Grupo RBS, especificamente à equipe de assinaturas digitais de GaúchaZH, portal de notícias locais que possui em média quinze milhões de usuários únicos mensais. O objetivo desta pesquisa é analisar a utilização de análise preditiva para extração de inteligência em táticas de *marketing*. Conclui-se que a aplicação consciente dos dados nas organizações representa um importante diferencial estratégico, sobretudo em um cenário no qual muitos *players* ainda se encontram em estágios incipientes de tratamento das suas informações. Portanto, a pesquisa se apresenta como fonte de referenciais para evoluções no uso de metodologias preditivas para aumento da efetividade e ROI de *marketing*.

**Palavras-chave:** Inteligência Antecipativa; Modelos preditivos; Marketing.

---

## 1 Introdução

O uso de modelos preditivos teve crescimento vinculado à geração dos dados que suportam a sua existência, vinculado à popularização do uso de novas tecnologias, como a internet. Segundo Witten et al. (2011), a cada 20 meses a quantidade de dados armazenada em todas as bases de dados do mundo duplica. Processos estruturados de mineração, análise e extração de inteligência se tornaram de suma importância para a sobrevivência de diversas organizações, tornando-se inclusive o centro da tomada de decisão de diversas empresas, sobretudo em um ambiente caracterizado pelo aumento exponencial da quantidade, da velocidade de geração e da variedade dos dados disponíveis, que são as três características que definem um dos termos mais em voga no mercado de dados e de *marketing* na atualidade, o *Big Data*. Exemplo de boa utilização de análise de tratamento e análise de dados é a Netflix, que analisa milhões de informações de seus espectadores, cruzando com as de consumo, para apontar combinações vencedoras para futuras produções (XU; FRANKWICK; RAMIREZ, 2016).

Segundo Nyce (2017), uma das possíveis utilizações do *Big Data* é a análise preditiva, envolvendo uso da grande massa de dados organizados na inferência de ações futuras de um determinado grupo de indivíduos importantes para a organização, prevendo eventos, novos comportamentos e até mesmo mudanças que, normalmente, não seria possível antecipar. Análise preditiva ou modelo preditivo é definido pela Gartner (2017, p.1) como "uma forma de análise avançada que examina dados ou conteúdos para responder perguntas". Trata-se de um modelo estatístico utilizado para identificar tendências, prever comportamentos, entender necessidades ou expectativas de clientes, promover a tomada de decisões baseadas em dados confiáveis e melhorar o desempenho dos negócios, podendo ser empregada em investigações policiais, previsões meteorológicas, criação de produtos, ou em estratégias de *marketing* (UDACITY, 2018).

Os modelos de análise preditiva se apoiam em técnicas estatísticas e de computação, como aprendizagem de máquina (*machine learning*) e a mineração de dados (*data mining*) para aumentar seu potencial de precisão (SALOMÃO, 2016). Segundo o projeto de ensino à distância de diversas empresas do Vale do Silício (como Google, Facebook, Tesla, Amazon e AirBNB) (UDACITY, 2018, p.2), o elemento central da análise preditiva é conhecido como preditor: "uma variável que pode ser medida para prever futuros comportamentos". Um modelo preditivo é simplesmente uma função matemática que é capaz de aprender

o mapeamento entre um conjunto de variáveis de entrada de dados, geralmente agrupadas em um registro, e uma variável de resposta ou de destino (IBM, 2017, p. 1).

Análises preditivas são largamente utilizadas no departamento de *marketing* de diversas organizações. Um dos usos mais comuns é para auxiliar na retenção de clientes, prevendo qual parcela da carteira da empresa possui maior propensão a cancelar o serviço e diminuir o *churn rate* - termo empregado para determinar a taxa de cancelamento de prestação de serviço (TARGETDATA, 2017). Outro uso muito comum da análise preditiva é no mercado de ações, ajudando os analistas de economia a prever macromovimentos econômicos ou, simplesmente, a queda no valor das ações de uma empresa específica (HAYASHI, 2017).

Nos últimos anos percebe-se uma pressão do mercado de trabalho para que o profissional de diversas áreas, como *marketing* e comunicação, amplie o seu grau de atuação para possuir a capacidade de trabalhar e extrair inteligência de uma quantidade exorbitante de dados. São novas exigências impostas aos profissionais (WEDEL; KANNEM, 2016). Em uma pesquisa realizada pela Accenture (CIO, 2018), 45% dos executivos entrevistados relataram um esforço de investimento das suas organizações para aumentar o volume de dados e até o uso de Inteligência Artificial (IA) para auxiliar na tomada de decisão dos seus funcionários em diversos níveis hierárquicos, como relata Andre Wilson, Chief Intelligence Officer da Accenture (CIO, 2018, p.1): “a partir do que os dados revelam, nossos funcionários podem ser mais bem sucedidos (nas suas tarefas), liberado-se para fazer outras coisas, como usar o seu tempo para focar nos clientes”.

Conforme Wedel e Kannen (2016), o perfil do analista de *marketing* precisa contemplar técnicas de modelagem do comportamento do cliente, de predição de respostas às ações propostas pela empresa, de otimização do *mix* de *marketing* a partir de dados e, sobretudo, de personalização (BIZZI; VIEIRA; LORO, 2017). Muito desse movimento se deve ao aumento da relevância do *marketing one-to-one* (PEPPERS; RODGERS, 2004), o *marketing* personalizado. O *marketing one-to-one*, segundo Hortinha (2001, p. 259), deve ser utilizado para conseguir uma relação personalizada com os clientes, de forma a conhecê-los o suficiente para poder oferecer a cada um os bens e serviços mais adequados. Em termos gerais, além de uma abordagem mais adequada e assertiva em *marketing*, a personalização ainda permite às empresas um maior controle de ROI (sigla em inglês para Retorno sobre o Investimento, ou seja, a lucratividade obtida a partir das ações tomadas) de cada tática operada.

Essa personalização do conteúdo não interessa apenas a quem o consome ou o produz, interessa e é impulsionada pela indústria publicitária, que encontra na segmentação uma arma importante na otimização e no maior controle dos resultados dos esforços publicitários dos seus anunciantes (PARISER *apud* ROSA, 2016, p.48).

A velocidade com qual a necessidade de novas disciplinas do conhecimento começa a ser exigidas para trabalhar com grandes volumes de dados aumenta proporcionalmente ao crescimento do volume de dados existentes, daí nasce a motivação para a presente pesquisa. Portanto, o objetivo do estudo é analisar, a partir de um estudo de caso, a utilização de modelagem de dados, especificamente a análise preditiva, para extração de inteligência em táticas de *marketing*. A intenção de estudo nesse segmento se dá por conveniência e pela percepção de escassez de estudos empíricos, visto que o tema ainda é pouco trabalhado em estudos acadêmicos, ainda que largamente empregado pelo mercado de *marketing* digital.

## 2 Referencial Teórico

### 2.1 Big Data

Segundo o Gartner Group (2014, p. 2), *Big Data* é definido "como ativos de alto volume, velocidade e variedade de informações que exigem custo-benefício, de formas inovadoras de processamento de informação para maior visibilidade e tomada de decisão". A IBM (2012) também define *Big Data* a partir das três dimensões citadas, mas acrescenta uma quarta dimensão, criando o conceito dos “4 Vs” como as quatro dimensões do *Big Data*: velocidade, variedade, volume e veracidade. Segundo Lam et al. (2016, p.1), *Big Data* se apresenta ao mercado como uma importante fonte de oportunidades para que as empresas e suas equipes de vendas possam ir "além dos dados transacionais e melhorem significativamente sua eficiência e eficácia nas suas linhas frente". Iyer et. al (2018, p.3) corroboram esse entendimento, acrescentando que "a digitalização, em quase todos os campos, transformou-se em muitas fontes de dados

e contribui para a criação de grandes volumes de dados, alguns dos quais são importantes para gerar conhecimento a partir de frentes de análise estatísticas".

Para Lam et al. (2016), *Big Data* são conjuntos de dados que possuem ao menos três características específicas, os três V's: (1) variedade, (2) velocidade e (3) volume. Já Carvalho (2015) e Iyer et al. (2018) ainda prevêem a existência de outras características, como a veracidade, ainda que não seja uma obrigatoriedade a um grupo de dados para que seja caracterizado como *Big Data*.

O uso do *Big Data* para geração de valor e diferencial competitivo já é uma realidade para as empresas nascidas digitalmente e para as empresas *data-driven*. Segundo Rubini (2017), as empresas estão buscando converter compras online em uma experiência personalizada do consumidor por meio da coleta e processamento de *Big Data*. É importante ressaltar que o uso de uma grande quantidade de dados para gerar diferencial competitivo não é nenhuma novidade (TARGETDATA, 2017), como frisado anteriormente neste projeto, porém o aumento do volume de dados somado ao uso de modelos estatísticos bem fundamentados tem se mostrado um gerador de diferenciação importante. Como será observado neste artigo, o comportamento dos usuários na internet, seja em portais de notícias, seja em redes sociais e outras fontes de entretenimento são grandes fontes de dados não estruturados (DI MARTINO et al., 2014), e são esses dados que, quando bem trabalhados pelas organizações que os possuem, podem gerar diferencial competitivo perante o mercado (DAVENPORT, 2012). Uma das aplicações possíveis para que um conjunto de dados se torne um diferencial para uma organização é a segmentação dos públicos-alvo (PARISER, 2012).

## 2.2 Segmentação

A segmentação de mercado é uma ação importante em todos os níveis estratégicos das organizações: da composição do *mix* de produtos (BIZZI; VIEIRA; LORO, 2017) até a composição das forças de vendas ou mesmo em ações logísticas. Segundo Schiffman e Kanuk (2000) existem sete bases para a segmentação do mercado: (1) geográfica; (2) demográfica; (3) psicográfica; (4) sociocultural; (5) relacionada com o uso; (6) por uso-situação; e (7) por benefício. Em termos gerais, a segmentação psicográfica é a que responde com melhor grau de complexidade e complementaridade às necessidades do *marketing* das organizações (AÑANA et al., 2008).

A segmentação psicográfica avalia somente quem está no segmento e o porquê do consumidor estar nele (THOMPSON; KAMINSKI, 1993), levando em conta atividades, interesses, opiniões (Activities, Interests and Opinions [AIO]), necessidades, valores, atitudes e traços de personalidade do consumidor (AÑANA et al. apud KAMINENI, 2005).

A busca por contextualização, ou segmentação, da oferta está intrinsecamente ligada à teoria da Cauda Longa criada por Anderson (2006), na qual o autor determina uma inversão na lógica de Pareto: ao invés de 20% dos produtos serem responsáveis por 80% das receitas de uma empresa, é a grande quantidade e variedade de produtos que traz a riqueza dos novos negócios digitais.

A maioria dos negócios de internet bem-sucedidos de alguma maneira explora a Cauda Longa. O Google, por exemplo, ganha boa parte de seu dinheiro não com grandes empresas anunciantes, mas com propaganda de pequenos negócios (a Cauda Longa da propaganda) (ANDERSON, 2006, p. 7).

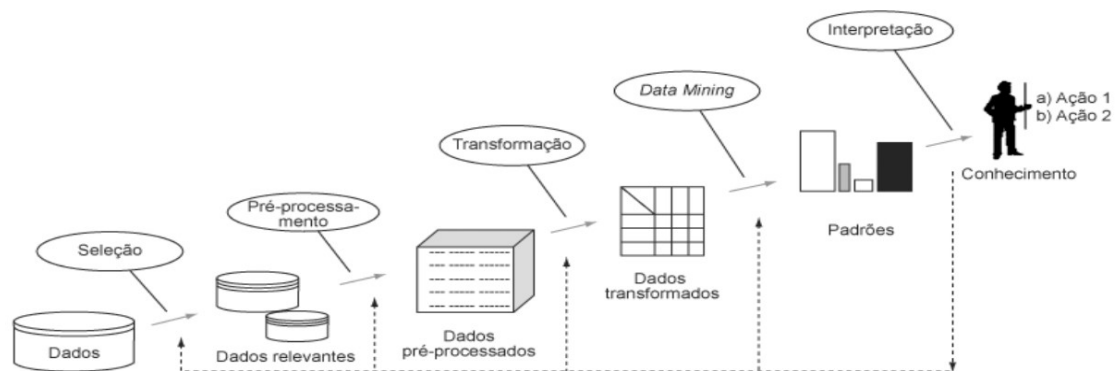
A lógica de Anderson (2006) pode ser ampliada não apenas para a efetivação da venda online, mas também para a oferta desses produtos ao cliente. A indústria publicitária encontra na segmentação uma arma importante na otimização e no maior controle dos resultados dos esforços publicitários dos seus anunciantes (PARISER, 2012). Uma das máximas da comunicação digital atual é que "atingir o público certo, com a peça certa, no momento certo" já não é mais apenas um jargão publicitário, mas sim uma realidade e uma imposição do mercado (ROSA, 2016).

É na necessidade latente de personalização e customização da relação entre organizações e consumidores, que o uso do *Big Data* se sobressai como uma estratégia importante. Como ressalta Jao (2013, p.1): "O *Big Data* possibilita marqueteiros a identificar cada comportamento dos seus usuários e conectá-lo a pontos que determinam a maneira mais efetiva de converter um usuário eventual (onetime customer) em consumidor fiel"; contudo, ressalta-se que para tal, são necessários métodos de extração de inteligência desses grandes volumes de dados (AKTER; WAMBA, 2016), como processos de mineração de dados.

### 2.3 Mineração de Dados

A mineração de dados é a extração de uma grande quantidade de dados e informações triviais com o objetivo de explorar padrões e correlações em um conjunto de dados (FINLAY, 2014). Braga (2005) define essa etapa, de suma importância para a construção de modelos de análise preditiva, como um processo de coleta, armazenagem, tratamento, análise e transformação de dados de um determinado período e contexto, a fim de transformá-los em informação, seja por meio de grafos, gráficos, nuvens de tags, etc. Para (ELMASRI e NAVATHE, 2005) mineração de dados se refere à descoberta de novas informações em função de padrões em grandes quantidades de dados.

O *data mining* é um dos processos do *Knowledge Discovery in Database* (KDD), ou seja, um importante processo de descobrimento de conhecimento em bancos de dados. O KDD é composto por seis etapas: seleção, pré-processamento, limpeza, transformação, mineração de dados e interpretação (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996). O fluxo pode ser percebido conforme a Figura 1.



**Figura 1: Etapas do processo KDD. Fonte: Fayyad, Piatetsky-shapiro e Smyth (1996).**

Segundo Ayres (2016), a mineração de dados possui dois tipos de tarefas possíveis: as preditivas (regressão e classificação) e as descritivas (associação e agrupamento). Segundo Nyce (2007), um dos componentes da análise preditiva é a mineração de dados, processo a que o autor se refere como sendo a análise de dados de modo a identificar tendências, padrões ou relações entre os dados, podendo esta informação ser posteriormente utilizada para desenvolver modelos preditivos.

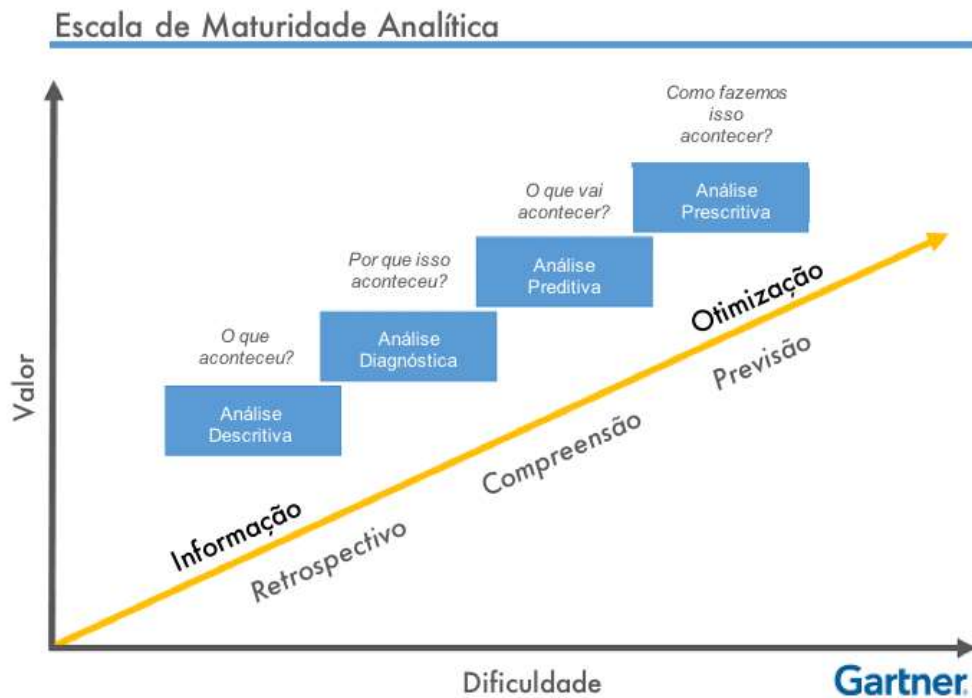
### 2.4 Análise Preditiva

Segundo Turban e Volonino (2017), análise preditiva é uma ferramenta aplicada sobre dados para a determinação de padrões para prever resultados e tendências futuras. Nyce (2007) define análise preditiva como um termo abrangente, englobando uma variedade de técnicas estatísticas e analíticas para desenvolver modelos capazes de prever eventos ou comportamentos futuros. O CIO (2018) define análise preditiva como:

Uma categoria de análise de dados destinada a fazer previsões sobre resultados futuros com base em dados históricos e técnicas de análise, como modelagem estatística e aprendizado de máquina. Pode gerar *insights* futuros com um grau significativo de precisão. Com a ajuda de sofisticados modelos e ferramentas de análise preditiva, qualquer organização agora pode usar dados passados e atuais para prever tendências e comportamentos de forma confiável em milissegundos, para dias ou anos no futuro (CIO, 2018).

O Gartner, como pode ser observado no gráfico da Figura 2, também o compreende como um processo com alto potencial de geração de valor para as organizações, porque as permite se antecipar a movimentos de mercado ou simplesmente oferecer o que seu consumidor quer no momento correto.





**Figura 2: Gráfico da geração de valor dos processos de análise de dados. Fonte: Propmodo (2018).**

As utilizações para a análise preditiva são diversas, como aponta o CIO (2016) na Tabela 1.

Área	Aplicação
Aeroespacial	Predição do impacto de operações específicas de manutenção, uso de combustível, disponibilidade e tempo de atividade da aeronave.
Automotivo	Incorporar registros de robustez do componente e falhas em futuros protótipos de veículos. Estudar o comportamento do motorista para desenvolver melhores tecnologias de assistência e até mesmo veículos autônomos.
Energia	Predição dos índices de preço e demanda a longo prazo. Determinação do impacto de eventos climáticos, falhas de equipamentos, regulamentações e outras variáveis nos custos de serviços.
Serviços financeiros	Desenvolvimento de modelos de risco de crédito. Previsão das tendências do mercado financeiro. Predição do impacto de novas políticas, leis e regulamentações sobre empresas e mercados.
Indústria	Predição da localização e da taxa de falha de máquinas. Otimização das entregas de matérias-primas com base nas demandas futuras projetadas.
Legal	Uso de dados de tendências criminais para definir os bairros que podem precisar de proteção adicional em determinadas épocas do ano.
Marketing	Acompanhamento em tempo real de um cliente <i>on-line</i> para determinar se o fornecimento de informações ou incentivos adicionais ao produto aumentará a probabilidade de uma transação concluída.

**Tabela 1. Aplicação de análise preditiva. Fonte: CIO (2016)**

Segundo a IBM (2017), os modelos preditivos de aprendizado podem ser supervisionados ou não supervisionados. No primeiro tipo, os dados são apresentados ao modelo com um padrão de entrada e um padrão de saída (inputs e outputs esperados) em repetição até que o modelo “compreenda” o que é esperado de um *input*. Já os modelos não supervisionados recebem apenas a entrada de dados e, por meio de uma combinação de cálculos matemáticos e estatísticos, chega ao resultado esperado (IBM, 2017). Em ambos os casos, é de suma importância que o volume de dados utilizado para as validações seja de larga escala e oriundo de uma base de qualidade, pois somente assim pode-se mensurar a assertividade do modelo.

Como abordado anteriormente, técnicas de análise preditiva têm sido implementadas largamente por diversas indústrias, como telefonia, para reduzir a taxa de abandono do serviço prestado (NIKULIN, 2016). Contudo, esse conceito de mineração de dados disponíveis e a aplicação de modelos de predição têm sido largamente utilizados também na aquisição de novos clientes. Diversas empresas de *marketing* digital, sobretudo em mídia e conteúdo, têm utilizado técnicas de análise preditiva para, por meio do cruzamento de informações da organização com dados disponíveis na internet, colocar a oferta do serviço em contato com a parcela de clientes mais propensos à compra. Segundo o portal especializado em ciência de dados CIO (2018), o gasto de mercado projetado com aplicação de análises preditivas manterá um crescimento anual de 21% entre 2016 e 2022, atingindo a marca de US\$ 10.95 bilhões em 2022. Assim como para Nyce (2007), para o CIO (2018), o conceito de análise preditiva é muito mais amplo do que a simples aplicação de uma técnica, é na realidade a junção de diversos processos para a extração de inteligência para as organizações:

A análise preditiva extrai seu poder de uma ampla gama de métodos e tecnologias, incluindo *Big Data*, mineração de dados, modelagem estatística, machine learning e diversos processos matemáticos. Organizações a usam para filtrar dados atuais e passados para detectar tendências e prever eventos e condições que devem ocorrer em um momento específico, com base nos parâmetros fornecidos (CIO, 2018).

Segundo o CIO (2018), existem quatro modelos de análise preditiva que, segundo a organização, permitem que os usuários se utilizem de dados passados e atuais para projeção de movimentos futuros, conforme a Tabela 2.

Modelo	Descrição/ Objetivo de identificação
Valor do tempo de vida do cliente	Clientes com maior probabilidade de investir mais em produtos e serviços.
Segmentação de clientes	Clientes do grupo com base em características semelhantes e comportamentos de compra
Manutenção preditiva	Chances de quebra do equipamento essencial.
Garantia de qualidade	Defeitos para evitar decepções e custos extras ao fornecer produtos ou serviços aos clientes.

**Tabela 2. Modelos de análise preditiva. Fonte: CIO (2018)**

### 3 Método

#### 3.1 Enquadramento

O estudo de caso do presente artigo segue o proposto por CIO (2018): uma aplicação de mercado de um conjunto de ações de mineração, tratamento de dados e aplicação de modelo estatístico para a extração de inteligência preditiva em ações de *marketing*. O método de pesquisa foi escolhido pois segundo Yin (2014, p.17), o estudo de caso nos permite "entender um fenômeno do mundo real e assumir que esse entendimento provavelmente englobe importantes condições contextuais pertinentes ao seu caso". Yin (2014) ressalta que o uso desse método deve ser feito quando as perguntas principais do pesquisador giram em torno do entendimento de um fenômeno essencialmente contemporâneo.

Deste modo, a abordagem da pesquisa é, em um primeiro momento, exploratória, pois permite ao pesquisador a possibilidade de conhecer mais o tema de análise (MATTAR, 1994), e também causal, pois



procura-se compreender o efeito do uso da ferramenta na conversão de assinaturas digitais. O método de pesquisa deste projeto é, portanto, um estudo de caso de dados secundários do Grupo RBS, oriundos de campanhas veiculadas entre fevereiro e abril de 2018. Para fins de proteção dos dados da empresa estudada, algumas informações foram omitidas, como: nomenclatura de fatores-chaves para a construção do modelo preditivo; números totais de impacto da aplicação do modelo preditivo e resultados obtidos a partir da aplicação do score.

### 3.2 Descrição do caso estudado

O Grupo RBS já utiliza de análise preditiva para redução de *churn* na carteira de assinantes do jornal Zero Hora. No ano de 2016, a empresa passou a utilizar modelos preditivos para também prospectar novos assinantes por meio de *call-center* ativo. No último trimestre de 2017, a empresa substituiu o site do jornal Zero Hora pelo projeto de *cobranding* junto à Rádio Gaúcha, GaúchaZH, reforçando o seu objetivo de aumentar a base de assinantes digitais. Passou, assim, a aplicar o modelo preditivo, especificamente regressão logística, em uma base de assinantes e *prospects* existentes. A partir dessa aplicação, criou-se o Modelo de Propensão à Aquisição, objeto de análise deste artigo.

O objetivo para a criação do Modelo de Propensão à Aquisição no Grupo RBS foi antever, dentro de um universo de 15 milhões de usuários únicos da plataforma de conteúdo GaúchaZH e de uma base de *prospects* totais de mais de 8 milhões de pessoas, qual cluster de usuários teria maior ou menor propensão à assinatura do produto. O ponto chave para a organização era, portanto, gerar um diferencial de negócio estratégico, que é o estabelecimento de estratégias antecipativas de *marketing* para aumento de carteira de clientes. Frisa-se, assim, que o objetivo do modelo é manter o foco em projeção de futuro, não em análise de dados passados (processo de descrição em *data mining*).

Como apontado anteriormente, a base total de *prospects* da organização é de mais de oito milhões de usuários que consomem diariamente os conteúdos do produto, gerando uma infinidade de informações a todo segundo e alimentando uma base de dados que cresce em ritmo extremamente acelerado. A técnica utilizada para estabelecimento do modelo foi a regressão logística, definida por Hair et al. (1998) como um modelo estatístico multivariado que permite estimar a probabilidade associada à ocorrência de determinado evento em face de um conjunto de variáveis explanatórias.

A regressão logística, como uma técnica preditiva, busca estimar a probabilidade da variável dependente assumir um valor, tendo em vista outras variáveis e seus valores. Caracteriza-se por descrever a relação entre variáveis independentes ( $X_i$ ) e uma variável dependente binária ( $Y$ ). Os resultados ficam contidos no intervalo de zero a um. Tendo em vista isto, criaram-se grupos de amostras justamente para atender ao requisito da técnica, que é ser aplicada em variáveis dependentes, no caso, binárias. O primeiro passo, portanto, foi o estabelecimento de uma amostragem para geração do modelo. No caso, foram estabelecidos dois públicos-alvo: (1) Assinantes de GaúchaZH e (0) *Prospects* de GaúchaZH. A distribuição das amostras pode ser observada na Figura 3.

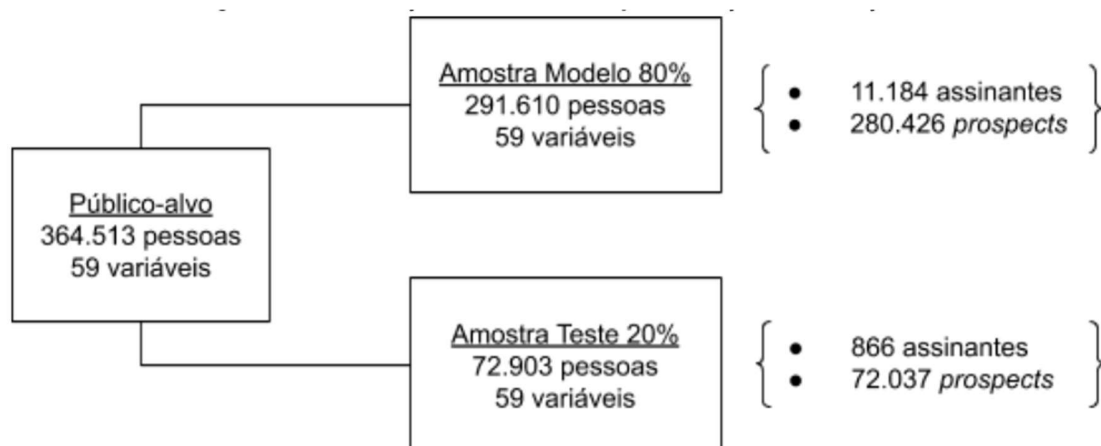


Figura 3: Distribuição das amostras para criação e validação do modelo

A regressão logística foi selecionada por atender às possibilidades do atual banco de dados do Grupo RBS, pela facilidade em trabalhar com variáveis independentes categóricas, por requerer um pequeno número

de suposições e por ter um alto grau de confiabilidade (USP, 2009). Não obstante os cálculos estatísticos não serem o foco do presente artigo, expõe-se na Figura 4 a equação, na qual é obtido o valor  $Y$ , a probabilidade do prospect se tornar um assinante.

$$E(Y) = \frac{1}{1 + \exp \left[ - \left( \beta_0 + \sum_{j=1}^k \beta_j X_j \right) \right]}$$

**Figura 4: Fórmula aplicada no estudo de caso**

Foram estabelecidas também 59 variáveis no estudo, sendo elas informações demográficas, de consumo e de uso que foram utilizadas para estabelecimento de um padrão de *score*, atendendo à exigência da técnica, que é a pontuação das variáveis de zero a um. O *score* é, assim, composto por informações básicas dos usuários como sexo e idade, mas também por informações mais complexas (e que são possíveis graças a sistemas mais sofisticados de captação de dados do usuário em *real time*) como editoriais de conteúdo consumidos, visitas a páginas específicas, *hits* de *paywall* (impactos de comunicação que o usuário recebe ao não ser assinante) e até mesmo contatos feitos pelo call-center da empresa. A cada variável foi atribuída uma pontuação (daí a nomenclatura *score*) positiva ou negativa e de diferentes grandezas, gerando, ao fim um placar geral para toda a base. Como exemplo: o usuário 1 que consome a Editoria 1, que possui pontuação positiva, tem maior propensão a assinar o serviço do que o usuário 2, que consome a Editoria 2, com menor pontuação que a primeira.

Do total de variáveis selecionadas para o modelo, nove foram identificadas com um alto valor de *score*, positivo ou negativo. A combinação de determinadas variáveis, conforme a pontuação obtida pela aplicação do modelo, foi capaz de estabelecer quais usuários da base total têm alto potencial em se tornarem assinantes ou têm baixo potencial de conversão. As principais variáveis encontradas foram:

- Visualizações de e-mail;
- Cliques de email;
- Quantidade de impactos por e-mail;
- Quantidade de impactos por telefonema;
- Gênero;
- Idade;
- Quantidade de *hits paywall*;
- Quantidade de *hits* no site GaúchaZH;
- Quantidade de *hits* no aplicativo Colorado ou Tricolor.

## 4 Resultados

Com uma diferença de 0,08 pontos percentuais no acerto global (ou seja, a capacidade do modelo em acertar se usuário é assinante ou não) da aplicação do modelo em Amostra Teste *versus* a Amostra Modelo, a técnica se mostrou efetiva para aplicação em toda a base de não assinantes que são *prospects*. Nas tabelas 3 e 4, pode-se perceber a assertividade das amostras e o resultado da aplicação sobre a base total: na Amostra Teste (Tabela 3) o acerto global foi de 71,19% e na Amostra Modelo (Tabela 4) foi de 71,28%. Já na Figura 5 é possível observar a variação do *score* na base de prospects.

Perfil	0 - Não assinante	1 - Assinante
0 - Não assinante	661	205
1 - Assinante	294	572

**Tabela 3. Amostra teste**

Perfil	0 - Não assinante	1 - Assinante
0 - Não assinante	8.386	2.798
1 - Assinante	3.629	7.555

Tabela 4. Amostra modelo




Figura 5: Gráfico da aplicação do modelo na base total de prospects

A aplicação direta do modelo foi feita por meio do *onboarding* da base de prospecção com maior *score* de conversão em plataformas de compra de mídia digital segmentada. Assim, cruzaram-se bases de sistemas externos com a base do modelo de propensão, promovendo assim a criação de perfis de alto engajamento nas ações de *marketing*. A aplicação do modelo na base existente não é, como citado anteriormente, o foco central da sua construção, mas se mostrou um potente exercício para clusterização da base e para o estabelecimento de diferentes táticas a serem tomadas por cada grupo de prospects.

Assim, diferentes ações foram tomadas para incentivar os usuários ao comportamento mais conversor, ou seja, permitiu à organização antecipar-se ao comportamento dos usuários e assim promover um comportamento de uso do seu serviço para engajar de maneira correta cada tipo de cliente, conforme o seu estágio (*score*) de conversão. Por exemplo, uma ação tomada foi a utilização de alguns fatores para elevar a probabilidade de vendas, como sugerir mais fortemente a leitura de editorias específicas ou aumentar/ diminuir os impactos em *hits* de *paywall*. Em resumo, foram tomadas três ações, uma para cada pontuação de *score*:

- Acima de 0,70: comunicação com foco em conversão;
- Entre 0,40 e 0,69:
  - Reforço de conteúdo em editorias específicas;
  - Estímulo ao acesso de páginas específicas;
  - Alteração do volume de *hits* em plataforma específica;
- Abaixo de 0,40:
  - Alteração do tipo de comunicação;
  - Engajamento do usuário para se logar.

Os resultados foram positivos para a organização, representando um investimento otimizado em publicidade e uma melhora no ROI das ações de marketing, além de promover um melhor entendimento da base de prospecção e auxiliar no estabelecimento de ações de aumento da base de alta conversão. Os resultados percentuais podem ser observados na Tabela 5.

	Antes do Modelo	1ª Aplicação do Modelo	2ª Aplicação do Modelo
<b>Conversão</b>	0,41%	1,38%	1,72%

**Tabela 5. Taxas de conversão**

## 5 Discussão

Observa-se a partir do entendimento de toda a estratégia e implementação do modelo de análise preditiva montado pelo Grupo RBS, uma complexa integração de diferentes fontes de dados. Se forem analisadas apenas as onze variáveis mais críticas na variação do score do modelo, são utilizados quatro sistemas diferentes, que serão descritos a seguir por finalidade (não serão mencionados os nomes das ferramentas por determinação da empresa estudada): disparo de *e-mail marketing* (EMM), controle de fluxo de *call-center*, CRM e análise do comportamento do usuário digital. Caso sejam levadas em conta as 59 variáveis presente no modelo inteiro, o número de bases utilizadas dobra de tamanho, o que demonstra o potencial de gerar um diferencial estratégico que o uso consciente e bem estruturado dos dados pode gerar às organizações.

Mais do que apenas a capacidade de utilizar os dados coletados e o conhecimento para implantar modelos de análise, tanto descritivos quanto preditivos, o caso pesquisado aponta para o quão ricos são os dados que a maioria das organizações, sobretudo aquelas inseridas no meio de consumo de produtos ou serviços digitais, como GaúchaZH, possuem. Seja uma plataforma de disparos de EMM simples como o MailChimp, seja um dashboard de visualização do comportamento do usuário como o Google Analytics, seja um CRM construído internamente em uma planilha de Excel, em algum nível de complexidade, todas as empresas ou *startups* com foco no consumo digital possuem informações ricas e de alto potencial de geração de diferencial competitivo.

A observação da evolução das taxas de conversão do sistema de aquisições de assinantes do Grupo RBS aponta o quão essencial para a consolidação de um crescimento além da curva-padrão do negócio, é a valorização dos dados gerados e coletados pelos negócios. Ainda que não possuísse uma taxa de conversão baixa nos seus esforços de *marketing* digital, a empresa atingiu um resultado, na média das duas aplicações presentes nesta pesquisa, quatro vezes superior com a aplicação de regressão logística, modelo de análise preditiva aplicado. Em uma era do *marketing* na qual a conversação customizada e única, consumidor a consumidor - conceito do *marketing one-to-one* de Peppers e Rodgers (2004) -, ganha mais importância no dia a dia das organizações, percebe-se que qualquer iniciativa de customização do contato empresa-cliente já influi diretamente no sucesso de ações de engajamento com o produto ou serviço ofertado. No caso de GaúchaZH/ Grupo RBS, uma das aplicações do modelo de extração de inteligência dos dados existentes foi recomendar a editoria de conteúdo correta para o usuário correto, fazendo-o, assim, percorrer mais um caminho no funil de conversões e aumentando a sua probabilidade em se tornar assinante do serviço.

Ressalta-se também que o modelo estudado apresenta uma união dados com diferentes características. Existem bases que podem ser definidas como *Big Data* pois possuem as três características principais apontadas por Lam et al. (2016) como essenciais: volume; variedade e velocidade. É o caso da variável "*Hits de Paywall*", por exemplo. Contudo, existem dados já existentes e não variáveis, que foram estruturados de uma maneira que, em rotinas de processamento programadas, são unidos às bases de *Big Data* e, a partir daí, são capazes de gerar inteligência à organização. Ressalta-se, assim, a importância de processos de análise das estruturas de dados existentes nas empresas, como um passo básico de entendimento do potencial real das informações que possui. O *data mining*, etapa do KDD (FAYYAD; PIATETSKY-SHAPIO; SMYTH, 1996) descrita anteriormente nesta pesquisa, é uma ferramenta importante de análise descritiva que pode auxiliar as organizações nesse processo anterior à predição de movimentos.

O que se aponta é que, ainda que muitas empresas não estejam em um estágio de Inteligência de Dados avançado o suficiente para aplicar modelos de inteligência antecipativa, como os do caso de GaúchaZH/ Grupo RBS, processos anteriores de conhecimento das potencialidades do que já existe dentro das organizações já podem se constituir em um diferencial. O Grupo RBS, como descrito no início desta pesquisa, construiu um caminho de amadurecimento no uso dos seus dados: passou por etapas de estruturação de bases, validação de potencialidades, utilização de modelos de predição mais simplificados em *call-center*, até utilizar-se de um modelo mais sofisticado em parceria com ferramentas externas de *marketing* digital. E, ainda assim, existem muitas outras aplicações, processos de inteligência e enriquecimento de dados possíveis para que o Grupo RBS amplie o seu modelo de predição.

Uma futura ampliação para o modelo preditivo de GaúchaZH/ Grupo RBS é o uso de *small data* dentro de suas análises, desde que haja um modelo de captação e processos estruturados de Inteligência Antecipativa para tal (LESCA; JANISSEK-MUNIZ, 2015). A utilização de sinais fracos do ambiente em que o consumidor de informação via meios digitais está inserido, bem como dos ambientes que envolvem os diferentes *stakeholders* e competidores da organização, pode se constituir em uma etapa de evolução interessante para o modelo de predição de assinantes do portal. Indica-se a análise dos processos estruturados de coleta de *small data* para o modelo da organização pela sua potencialidade em incrementar o modelo de predição para além do que os dados de massa podem apontar e pela facilidade - ao menos aparente - que o Grupo RBS possui em obter tais dados: uma área de contato direto com o cliente (retenção via canais digitais e *call-center*); equipe de Inteligência de Mercado bem estruturada e vastas ferramentas de análise de conteúdo em mídias sociais, por exemplo.

## 6 Conclusão

O objetivo do presente estudo foi analisar a utilização de modelagem de dados, com foco em análise preditiva, para extração de inteligência em táticas de *marketing*. Por meio do caso estudado, no qual foi possível implementar a análise preditiva em uma base de usuários, confirmou-se o caráter benéfico do uso de ferramentas de tratamento de dados para predição de movimentos estratégicos aos objetivos de uma organização. A hipótese validada a partir da análise do caso da presente pesquisa em adição aos dados levantados na revisão teórica apontam que o levantamento de estratégias e táticas de *marketing* das empresas, cada vez mais, precisará estar ancorado em um processo bem estruturado de extração de inteligência nos dados existentes na organização.

A antecipação dos movimentos do usuário representa uma importante vantagem para melhoria no ROI das operações de *marketing* das organizações e também de produto, visto que pode tanto ampliar a aceitação do produto/ serviço ofertado quanto engajar e aprofundar o seu uso. A maior assertividade dessas operações deve-se à personalização dos pontos de conversação cliente-serviço, não limitando-se ao uso do primeiro nome do cliente em um email *marketing* ou em uma ligação, mas poupando-se o seu tempo e lhe oferecendo o conteúdo que ele deseja.

Como citado anteriormente, sabe-se que muitas empresas não possuem o nível de maturidade necessário para o uso de modelos complexos de tratamento de dados para construção de modelos de análise preditiva. Contudo, a cultura de conhecimento dos dados, bem como do seu bom uso e tratamento, é de suma importância para as organizações. O gasto de energia e recursos em ações de *marketing* sem validação prévia de potencial de assertividade se torna cada vez mais nocivo para as empresas no cenário de alta competitividade, sobretudo do mercado de produtos e serviços digitais.

O número de aplicações (duas) do modelo de predição utilizado como estudo de caso para esta pesquisa é uma de suas limitações, pois não se pôde isolar determinadas variáveis como: (1) época do ano em que as campanhas foram veiculadas; (2) criativos utilizados nas peças publicitárias; e (3) preço. Esses fatores impactam diretamente no resultado de um esforço de *marketing*. Ainda que tenham sido controlados ao máximo pelo Grupo RBS, poderiam ser mais bem isoladas com um número maior de aplicações.

Outra limitação que se aponta é a utilização de apenas um estudo de caso, pois não permite a comparação das taxas de sucesso com outros segmentos de produtos ou serviços. O uso de dois ou mais estudos de caso também possibilitaria a comparação do uso das bases em outras ferramentas de *marketing*, diferentes das utilizadas pelo Grupo RBS ou, até mesmo, outras estratégias de tratamento dos dados das organizações.

Por fim, indica-se a ampliação da abordagem acadêmica para: (1) melhoria ou otimização dos métodos estatísticos e matemáticos aplicados em modelo de predição; (2) ampliação dos tipos de dados utilizados

nos modelos; (3) implementação e teste de outros processos de coleta de dados para o enriquecimento dos modelos preditivos baseados apenas em grandes volumes de dados.

## 7 Referências

- Akter, S., & Wamba, S. (2016). Big data analytics in E-commerce: a systematic review and agenda for future research. *Electronic Markets*, 26(2), 173-194. doi: 10.1007/s12525-016-0219-0.
- Añaña, E., Vieira, L. M., de La Martinière Petroll, M., Petersen-Wagner, R., & Simm Costa, R. (2008). As comunidades virtuais e a segmentação de mercado: uma abordagem exploratória, utilizando redes neurais e dados da comunidade virtual Orkut. *RAC-Revista de Administração Contemporânea*, 12(Esp).
- Anderson, C. (2006). *A Cauda Longa: a nova dinâmica de marketing e vendas: como lucrar com a fragmentação dos mercados*. Rio de Janeiro, RJ: Elsevier.
- Ayres, R. (2016). *KDD, Mineração de Dados e Algoritmo Apriori* (Mestrado). Universidade Federal de São Carlos - UFSCar.
- Braga, L. P. V. B. (2005). *Introdução à Mineração de Dados-2a edição: Edição ampliada e revisada*. Editora E-papers.
- Davenport, T. H., & Patil, D. J. (2012). Data scientist. *Harvard Business Review*, 90(5), 70-76.
- Bizzi, M., Vieira, C., & Louro, A. (2018). Análise Preditiva do Perfil dos Investidores do Tesouro Direto Para Ações de Marketing. In *XX SemeAd - Seminários de Administração*. São Paulo, de <http://login.semead.com.br/20semead/arquivos/1866.pdf>
- Di Martino, B., Aversa, R., Cretella, G., Esposito, A., & Kołodziej, J. (2014). Big data (lost) in the cloud. *International Journal of Big Data Intelligence*, 1(1-2), 3-17.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). The KDD process for extracting useful knowledge from volumes of data. *Communications of The ACM*, 39(11), 27-34. doi: 10.1145/240455.240464
- Finlay, S. (2014). *Predictive analytics, data mining and big data*. London: Palgrave Macmillan.
- Gama, J., Carvalho, A. C. P. D. L., Faceli, K., Lorena, A. C., & Oliveira, M. (2015). *Extração de conhecimento de dados: data mining*.
- Guazzelli, A. (2018). *O Que é a Análise Preditiva?* de <https://www.ibm.com/developerworks/br/industry/library/ba-predictive-analytics1/index.html>
- Hair, J. F., Anderson, R. E., Tatham, R. L., & Black, W. C. (1998). *Multivariate data analysis*. Upper Saddle River.
- Hayashi, A. H. (2017). *Processo para predição de preços das ações no mercado financeiro com o uso de Big Data* (Dissertação de Mestrado. IPT-São Paulo).
- IBM. (2018). *Analytics: The real-world use of big data [Ebook]*. Oxford: Said Business School - University of Oxford, de <https://www.bdvc.nl/images/Rapporten/GBE03519USEN.PDF>
- Jao, J. (2013). *Why big data Is A must In ecommerce*, de <http://www.bigdatalandscape.com/news/why-big-data-is-a-must-in-ecommerce/>
- Lam, S., Sleep, S., Hennig-Thurau, T., Sridhar, S., & Saboo, A. (2016). Leveraging Frontline Employees' Small Data and Firm-Level Big Data in Frontline Management. *Journal Of Service Research*, 20(1), 12-28. doi: 10.1177/1094670516679271
- Lesca, H., Janissek-Muniz, R. (2015) *Inteligência Estratégica Antecipativa e Coletiva: o Método L.E.SCAanning*. Porto Alegre RS.
- Mattar, F. N. (1994). *Pesquisa mercadológica*. São Paulo: Atlas, 1.
- Target Data. *Modelos preditivos: transforme dados em resultados*. (2018), de <https://www.targetdata.com.br/modelos-preditivos-transforme-dados-em-resultados/>
- Navathe, S. B., & Elmasri, R. (2005). *Sistemas de banco de dados*. Ribeirão Preto SP.



- Nikulin, V. (2016). Prediction of the Shoppers Loyalty with Aggregated Data Streams. *Journal Of Artificial Intelligence And Soft Computing Research*, 6(2), 69-79. doi: 10.1515/jaiscr-2016-0007
- Nyce, C., & Cpcu, A. (2007). Predictive analytics white paper. *American Institute for CPCU. Insurance Institute of America*, 9-10.
- Pariser, E. (2012). *O filtro invisível: o que a internet está escondendo de você*. Zahar.
- Peppers, D. O. N., & Rogers, M. (2004). AMA redefine o marketing: o que importa é o cliente. *Inside1to1*, 11.
- Predictive Analytics (2017). *Gartner IT Glossary*. Disponível em: <https://www.gartner.com/it-glossary/predictive-analytics-2/>
- Propmodo. (2018). *Analytic Value Escalator [Imagem]*. Disponível em: <https://propmodo.com/inside-hacker-connect-2018-predictive-analytics-biometrics-blockchain/>
- Rosa, L. (2016). *Impactos do advento da comercialização programática de mídia digital no mercado publicitário brasileiro*. UFRGS.
- Rubini, A. (2017). *Fintech in a flash*. CreateSpace Independent.
- Salomão, K. (2016). *Google ajudou a movimentar até R\$ 37 bi na economia brasileira*. Disponível em: <https://exame.abril.com.br/negocios/google-ajudou-a-movimentar-ate-r-37-bi-na-economia-brasileira>
- Schiffman, L. G., & Kanuk, L. L. (2000). *Consumer behavior*, 7th. NY: Prentice Hall, 15-36.
- Taylor, L., Schroeder, R., & Meyer, E. (2014). Emerging practices and perspectives on Big Data analysis in economics: Bigger and better or more of the same? *Big Data & Society*, 1(2).
- Thompson, A. M., & Kaminski, P. F. (1993). Psychographic and lifestyle antecedents of service quality expectations: a segmentation approach. *Journal of Services Marketing*, 7(4), 53-61. doi: 10.1177/2053951714536877
- Turban, E., & Volonino, L. (2013). *Tecnologia da Informação para Gestão-: Em Busca de um Melhor Desempenho Estratégico e Operacional*. Bookman Editora.
- Yin, R. (2014). *Case study research*. London: Sage Publication.
- UDACITY (2018). *Análise preditiva na tomada de decisão*. Disponível em: <https://br.udacity.com/blog/post/analise-preditiva-tomada-decisao>
- Edwards, J. (2018). *What is predictive analytics? Transforming data into future insights*. Disponível em: <https://www.cio.com/article/3273114/predictive-analytics/what-is-predictive-analytics-transforming-data-into-future-insights.html>
- USP. (2009). *Regressão Logística*. Presentation, São Paulo.
- Wedel, M., & Kannan, P. K. (2016). Marketing Analytics for Data-Rich Environments. *Journal of Marketing*, 80(6), 97-121. doi: 10.1509/jm.15.0413
- Witten, D. M., & Tibshirani, R. (2011). Penalized classification using Fisher's linear discriminant. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 73(5), 753-772.
- Xu, Z., Frankwick, G. L., & Ramirez, E. (2016). Effects of big data analytics and traditional marketing analytics on new product success: A knowledge fusion perspective. *Journal of Business Research*, 69(5), 1562-1566.
- Yver et. al. (2018). BIG DATA ANALYTICS: THE STAKES FOR STUDENTS, SCIENTISTS & MANAGERS. *In EeL Conference*. Singapura. Disponível em: <https://arxiv.org/ftp/arxiv/papers/1803/1803.05991.pdf>

### **Luccas Martins da Rosa**

Graduação em Publicidade pela UFRGS, com Especialização em Inteligência Estratégica (UFRGS) e MBA em Gestão Estratégica de Negócios (ESPM-Sul), com atuação desde o início da sua carreira na intersecção entre publicidade e tecnologia. É especialista no mercado Martech com experiência em diversas camadas desse mercado: experiência com planejamento de mídia (foco em mídias digitais), desenvolvimento de negócios em mídia programática e atuação como Product Owner de monetização B2B digital; com experiência mais recente em liderança de operação comercial digital

**Raquel Janissek-Muniz**

Head do IEA Future Lab. Professora e Pesquisadora [PPGA/EA/UFRGS]. Precursora no Brasil do conceito de Inteligência Estratégica Antecipativa - Método LESCAnning. Doutorado em Inteligência Antecipativa pela UPMF (Université Pierre Mendès France de Grenoble - France). Pós-Doutorado em Administração GIANTI-PPGA/EA/UFRGS. Master Sciences DEA/MATIS na Université de Genebra-Suíça. Master DEA en Systèmes d'Information - UPMF. Mestrado em Administração (UFRGS). Coordenadora da Área de Gestão em Sistemas e Tecnologia da Informação [GSTI] PPGA/UFRGS. Coordenadora do Grupo de Pesquisa em Inteligência [CNPq]. Coordenadora do Curso de Especialização em Inteligência Estratégica (UFRGS). Consultora de Inteligência e formadora de times de Inteligência Antecipativa.